

基于DTW匹配的粒子滤波故障预报^①

蒋欣, 王开军, 陈黎飞

(福建师范大学 数学与计算机科学学院 福建省网络安全与密码技术重点实验室, 福州 350007)

摘要: 现有的粒子滤波故障预报方法主要是通过粒子滤波算法得到对应时刻的预测值, 然后比较预测序列与观测序列的距离来对故障进行预报, 但这种基于相同长度时间序列的故障预报方法不能处理预测序列与观测序列长度不同的情况. 本文借助适用于不同长度时间序列的动态时间弯曲技术, 对故障相关的时间序列进行分析, 从动态时间弯曲算法度量设备正常工作的时间序列与潜在故障引起的异常序列之间相似度的角度, 设计了系统正常度及反常度来判别设备是否正常运行, 进而对潜在故障进行预报. 实验结果验证了该方法的可行性, 并能及时准确地预报出系统故障.

关键词: 动态时间弯曲; 粒子滤波; 正常度; 反常度; 故障预报

Particle Filter Fault Prediction Based on Dynamic Time Warping Match

JIANG Xin, WANG Kai-Jun, CHEN Li-Fei

(Fujian Province Network Security and Cryptography Laboratory, Mathematics and Computer Science College, Fujian Normal University, Fuzhou 350007)

Abstract: The existing particle filter fault prediction methods give the predictive value of the corresponding time by the particle filter algorithm, and then compare the distance between forecasting sequence and observation sequence to predict the fault. However, this fault prediction method can not handle the condition that the length of forecasting sequence is different from that of observation sequence. Dynamic Time Warping is a pattern matching algorithm based on nonlinear, which is suitable for the time sequence of different lengths. This paper is from the new perspective of using the Dynamic Time Warping algorithm to measure the similarity between normal working equipment's time sequence and abnormal sequence caused by potential faults, and design the system normal degree and abnormal degree to distinguish whether the device is operating properly or not, thus predict potential faults. Experimental results demonstrate the feasibility of this method, which can predict the system faults timely and accurately.

Key words: dynamic time warping; particle filter; normal degree; abnormal degree; fault prediction

1 引言

随着现代工业的迅速发展, 重大技术设备通常以复杂混合系统的形式出现, 设备一但出现故障后, 会造成严重的经济损失, 甚至产生无法弥补的后果, 因此故障预报是避免设备发生故障而造成严重损失的重要措施. 所谓故障预报即根据系统以前的状态, 判断当前状态偏离正常态的程度, 以及预报故障发生时间^[1], 根据预报可以对设备提前进行维修. 文献[2]中提出用

“健康指数”(Health Index, HI)描述复杂系统状态, 文献[3]给出了设备可能出现的三种状态, 即正常状态、性能下降状态以及功能失效状态.

目前故障预测的方法^[4]主要分为: 基于模型的故障预测方法(model-based approach)、基于知识的故障预测方法(knowledge-based approach)、基于数据的故障预测方法(data-driven approach)三大类. 本文所涉及的粒子滤波算法对系统目标进行跟踪预测属于基于数据

^① 基金项目:福建省自然科学基金(2013J01223);国家自然科学基金(61175123);福建师范大学“网络与信息安全关键理论和技术”校创新团队(IRTL1207)

收稿时间:2015-02-11;收到修改稿时间:2015-04-26

的故障预测方法,该方法能有效的解决现代设备非线性非高斯系统的故障预测问题^[5],目前已被广泛应用于诸多领域^[7],在经济学领域,它被应用在经济数据预测;在军事领域已经被应用于雷达跟踪空中飞行器,空对空、空对地的被动式跟踪;在交通管制领域它被应用在对车或人视频监控.目前,最常见的模式匹配方法包括欧几里得距离、曼哈顿距离、切比雪夫距离等,本文提出一种基于动态时间弯曲(DTW, Dynamic Time Warping)匹配的新方法,在故障预报阶段,采用DTW算法度量设备正常工作的时间序列数据与潜在故障引起的异常数据之间的相似性来进行故障预报,以期进一步提高故障预报的及时性和准确性.

2 相关理论

设备运行期间,可得到设备实际的运行数据,根据设备当前运行的实际数据,采用粒子滤波算法可对目标进行跟踪,得到设备运行的下一段时间预测数据.

2.1 经典粒子滤波算法

粒子滤波是一种顺序重要性采样方法,其核心思想是通过一组在状态空间传播的随机样本(粒子)对概率密度函数进行近似.由于粒子滤波算法是采用一些具有权值的随机样本(粒子)来表示所需的后验概率密度,而不是采用线性变换的传统方式,从而得到基于物理模型的近似最优解,其具有精度高、收敛速度快等优点.

现假设电子设备的故障演化过程可用如下状态空间模型表示:

$$X_k = f(X_{k-1}, \theta_k, I_{k-1}) + w_{k-1} \quad (1)$$

$$Y_k = h(X_k, \theta_k) + u_k \quad (2)$$

其中 X_k 是系统的状态变量,它的值直接与设备的故障演化过程相关, Y_k 是系统的观测变量, θ_k 是模型的参数,一般用于表示设备故障演化导致的模型参数的变化, w_k 和 u_k 分别为系统噪声和观测噪声.

粒子滤波算法在本文中被我们用于对目标的跟踪预测,其基本过程描述如下:

1) 初始化

初始时刻 $T = 0$ 时,抽样生成服从先验分布 $P(X_0)$ 的 N 个样本粒子 $\{x_0^1, x_0^2, \dots, x_0^N\}$, 每个粒子的权重值 w_0^i 设为 $1/N$. 在 $T=k-1$ 时,抽样生成服从先验分布 $p(x_{k-1} | y_{1:k-1})$ 的 N 个样本粒子 $\{x_{k-1}^1, x_{k-1}^2, \dots, x_{k-1}^N\}$

2) 预测更新状态变量

采用 $k-1$ 时刻 N 个独立同分布的样本粒子计算 k 时刻的样本粒子值: $\tilde{x}_k^{(j)} = f(x_{k-1}^{(j)})$

3) 计算权值并进行归一化

更新 k 时刻样本的权值: $w_k^{(j)} = w_{k-1}^{(j)} p(y_k | x_k^{(j)})$

对权值进行归一化: $w_k^j = w_k^j / \sum_{j=1}^N w_k^j$

4) 输出滤波结果

计算出 k 时刻状态变量的值: $\tilde{x}_k = \sum_{j=1}^N w_k^j x_k^j$

5) $K=K+1$, 重复第 1 步至第 4 步

2.2 动态时间弯曲概念

设时间序列向量 $X=(x_1, x_2, \dots, x_n)^T$ 和 $Y=(y_1, y_2, \dots, y_m)^T$ 具有不同的序列长度,即 $n \neq m$. 为了利用 DTW 算法将两个时间序列对准,需先定义一距离相异矩阵.

定义 1. (距离相异矩阵) 两个不同长度时间序列向量 $X=(x_1, x_2, \dots, x_n)^T$ 和 $Y=(y_1, y_2, \dots, y_m)^T$, 距离相异矩阵 d_{xy} 定义如下所示:

$$d_{xy} = \begin{bmatrix} d(x_1, y_1) & d(x_1, y_2) & \cdots & d(x_1, y_m) \\ d(x_2, y_1) & d(x_2, y_2) & \cdots & d(x_2, y_m) \\ \vdots & \vdots & \ddots & \vdots \\ d(x_n, y_1) & d(x_n, y_2) & \cdots & d(x_n, y_m) \end{bmatrix} \quad (3)$$

其中 $d(x_i, y_j) = |x_i - y_j|$ 为两个时间序列中数据点 x_i 与 y_j 之间的曼哈顿距离,可看作序列 X 和序列 Y 之间相异性的量化表示. 当时间序列 X 和 Y 越相似时,上述矩阵中 $d(x_i, y_j)$ 的值也越小,反之两个序列越不相同则其值越大.

DTW 算法是用来度量两个时间序列之间距离的匹配方法,其核心为动态规划思想,通过在两个时间序列中寻找最佳的采样点,很好的解决了不同长度时间序列的匹配计算问题. 时间序列向量 X 和 Y 之间的 DTW 距离的计算公式如下:

$$D(i, j) = \min \begin{cases} D(i-1, j) \\ D(i-1, j-1) \\ D(i, j-1) \end{cases} + d(x_i, y_j) \quad 1 \leq i \leq n, 1 \leq j \leq m \quad (4)$$

上述递归公式 $D(i, j)$ 和距离函数 $d(x_i, y_j)$ 可根据实际应用的不同进行相应的设计,通常情况下 $d(x_i, y_j)$ 采用欧式距离, $D(0, 0)$ 默认初始值一般设为 0.

定义 2. (DTW 匹配距离) 两个不同长度时间序列向量 $X=(x_1, x_2, \dots, x_n)^T$ 和 $Y=(y_1, y_2, \dots, y_m)^T$ 代入定义 1 中可得出两个序列间的距离相异矩阵,然后代入公式(4)最终求得的值 $D(n, m)$ 则为序列 X 和序列 Y 的 DTW 匹配距离,即

$$D_{xy} = D(n, m) \quad (5)$$

当两个序列完全相等时, D_{xy} 值为 0, 反之两个序列 X 和序列 Y 越不接近, D_{mn} 值越大, 有关 DTW 算法的更多细节及其伪代码实现参见文献[10].

3 基于DTW匹配的粒子滤波故障预报算法

假设设备初始为正常工作状态, 随着工作时间的增加, 逐渐发展为性能下降状态, 最后变为功能失效状态。本文采用 DTW 算法来度量设备运行的实际数据与根据粒子滤波算法得出的预测数据两者之间的相似性。实际数据与预测数据越接近, 相似性越大, 则认为设备处于正常工作状态, 反之实际数据与预测数据偏离越远, 相似性越小, 认为设备发展为性能下降状态。

3.1 算法原理

当前时刻为 k 时, 已知观测变量 y 当前时刻 k 及前一段时间数据 $\{y_1, y_2, \dots, y_{k-1}\}$, 根据粒子滤波算法进行 q 步反向预测, 可得反向预测序列 $\{\tilde{y}_{k-q}, \tilde{y}_{k-q+1}, \dots, \tilde{y}_{k-1}\}$, 然后根据动态时间弯曲(DTW)算法将反向的预测序列 $\{\tilde{y}_{k-q}, \tilde{y}_{k-q+1}, \dots, \tilde{y}_{k-1}\}$ 与设备前期正常工作状态观测序列 $\{y_6, y_7, y_8, y_9, y_{10}\}$ (设监测的设备初期为正常工作状态, 随时间推移逐步发展为性能下降状态或功能失效状态)代入公式(5)计算其反方向对应的 DTW 匹配距离, 进一步计算设备在时刻 T_k 偏离正常工作状态程度的反常度; 同时, 我们也进行 p 步向前预测, 可得出正向预测序列 $\{y_{k+1}, y_{k+2}, \dots, y_{k+p}\}$, 当到达 $k+m$ 时刻时, 根据动态时间弯曲(DTW)算法将预测序列 $\{y_{k+1}, y_{k+2}, \dots, y_{k+p}\}$ 与实际观测序列 $\{y_k, y_{k+1}, \dots, y_{k+m}\}$ 代入公式(5)计算其 DTW 匹配距离 (其中 $m \neq p$), 度量两者之间的相似性, 再进一步计算在时刻 T_{k+m} 设备符合正常工作状态程度的正常度。

在设备故障预测中, 常规的做法是比较当前时刻预测序列与观测序列的欧几里得距离, 从而在一定准则意义下进行故障预报, 但该方法受到个别异常点影响很大, 鲁棒性较差, 而且欧式距离不能度量不同长度的预测序列和观测序列的相似程度, 相比之下, 动态时间弯曲算法受个别异常点影响较小, 同时其能比较不同长度序列的相似程度。本文采用 DTW 算法度量两个序列 (例如前文中 $\{y_k, y_{k+1}, \dots, y_{k+m}\}$ 和 $\{y_{k+1}, y_{k+2}, \dots, y_{k+p}\}$) 之间的相似程度, 从而实现故障的诊断, 以期实现更为合理的故障预测。

定义 3. (正常度) 在时刻 t , 系统的正常度定义如下:

$$H_t = e^{-D_{xy}(t)} \quad (6)$$

同理 $D_{xy}(t)$ 为对应 t 时刻实际值序列 X 和预测值序列 Y 之间的 DTW 匹配距离。若系统运行正常, 则时刻 t 的实际序列和预测序列相似程度较高, DTW 匹配距离较小, 正常度较高, 反之系统逐渐变为失效状态, 实际值和预测值相似程度越来越低, DTW 匹配距离越来越大, 正常度也越来越低。

定义 4. (反常度) 在时刻 t , 系统的反常度定义如下:

$$F_t = 1 - e^{-D_{xy}(t)} \quad (7)$$

其中, $D_{xy}(t)$ 为对应 t 时刻实际值序列 X 和预测值序列 Y 之间的 DTW 匹配距离。假设设备故障发展初期系统处于正常状态, 随着时间的推移和潜在故障的发展, 实际值和预测值偏离越来越大, DTW 匹配距离越来越大, 反常度逐步变高, 对应故障概率逐步变大。

3.2 故障预测算法步骤

Step 1: 设备运行初期, 系统处于正常状态, 测量获得数据 $\{y_t\} (t=1, 2, 3, \dots)$ 。

Step 2: 当时间 $t=k$ 时, 通过公式(1)和(2)以及粒子滤波算法进行 p 步向前预测得到预测序列 $\{\tilde{y}_{k+1}, \tilde{y}_{k+2}, \dots, \tilde{y}_{k+p}\}$, 当时刻到达 $k+m$ 时与实际值序列 $\{y_k, y_{k+1}, \dots, y_{k+m}\}$ 代入公式(5)计算序列之间的 DTW 匹配距离。

Step 3: 将计算所得 DTW 匹配距离代入公式(6)求得正常度。

Step 4: 在时刻 $t=k (k > q)$, 反向使用公式(1)和公式(2)以及粒子滤波算法进行 q 步反向预测, 得到反向预测序列 $\{\tilde{y}_{k-q}, \tilde{y}_{k-q+1}, \dots, \tilde{y}_{k-1}\}$, 将这一反向预测序列与设备前期观测序列 $\{y_6, y_7, y_8, y_9, y_{10}\}$ 代入公式(5)计算其 DTW 匹配距离。

Step 5: 将计算所得 DTW 匹配距离代入公式(7)求得其反常度。

Step 6: 当时刻 t 出现反常度连续两次大于正常度, 则预报系统出现故障, 设备需检修。

4 实验结果与分析

本节通过实验来检测本文方法的有效性, 性能评价考察在故障发生后多长时间预报故障, 并与基于随

机摄动粒子滤波器的故障预报算法^[12]和基于粒子滤波的 FDI 方法^[13]进行对比. 仿真实验采用文献[12]中德国 Amira 公司制造的三容水箱系统, 如图 1 所示. 在此装置中, 有 3 个垂直放置并且大小一致的玻璃圆筒 T1、T2、T3, 圆筒横截面积均为 A, 各圆筒由横截面为 S_n 的圆管相连接, 圆筒 T2 下方的出水阀可控制水流到下方的玻璃水箱中, 同时圆筒 T1、T2、T3 下方各有一个泄漏阀(截面积都为 S_1). 两台水泵分别向圆筒 T1、T2 输入流量为 Q_1 、 Q_2 的循环水, 它们是系统的输入, 系统状态变量为三个圆筒水槽 T1、T2、T3 的液位 h_1 、 h_2 、 h_3 .




图 1 三容水箱系统

三容水箱系统离散化的状态空间模型为^[12]:

$$\begin{cases} x(k+1) = x(k) + \Delta t \cdot A(x) + \Delta t \cdot B \cdot o(k) + u(k) \\ y(k) = x(k) + v(k) \end{cases} \quad (8)$$

其中, 系统状态变量 $x = [x_1 \ x_2 \ x_3]^T = [h_1 \ h_2 \ h_3]^T$, 初始液面高度 $h_1^0 = 0.4\text{m}$, $h_2^0 = 0.3\text{m}$, $h_3^0 = 0.35\text{m}$, $h_{\max} = 0.62\text{m}$, 高斯系统噪声 $u \sim N(0, 2 \times 10^{-4})$, 系统的输入 $o = [Q_1 \ Q_2]^T$, $Q_1 = Q_2 = 4.5 \times 10^{-5} \text{m}^3/\text{s}$, $Q_{1\max} = Q_{2\max} = 10^{-4} \text{m}^3/\text{s}$, 抽样间隔 $\Delta t = 0.054$, y 为观测变量, 高斯观测噪声 $v \sim N(0, 10^{-4})$; 其余参数如下:

$$A(x) = \frac{1}{A} \begin{bmatrix} -Q_{13} \\ Q_{32} - Q_{20} \\ Q_{13} - Q_{32} \end{bmatrix}, \quad B = \frac{1}{A} \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix}$$

$$Q_{13} = az_1 S_n \operatorname{sgn}(h_1 - h_3) (2g |h_1 - h_3|)^{1/2},$$

$$Q_{32} = az_3 S_n \operatorname{sgn}(h_3 - h_2) (2g |h_3 - h_2|)^{1/2},$$

$$Q_{20} = az_2 S_n (2gh_2)^{1/2},$$

$$A = 0.0154 \text{m}^2, \quad S_n = 5 \times 10^{-5} \text{m}^2, \quad g = 9.81 \text{m/s}^2, \quad az_1^0 = 0.5,$$

$$az_2^0 = 0.6, \quad az_3^0 = 0.5.$$

设计系统在 20 个抽样时间间隔 ($20\Delta t$) 后开始逐渐出现故障, 出现故障后圆筒 T2 的液位不能保持初始值

而大幅下降, 即加入 az_2 参数故障, 让 az_2 按下式^[12]变化:

$$az_2 = \begin{cases} 0.6 & 0 < k \leq 20 \\ az_2^0 + 0.06(k-20) & 20 < k \leq 80 \\ 4.2 & 80 < k \end{cases} \quad (9)$$

在实验中, 设计系统的仿真运行时间是 $200\Delta t$, 仿真系统在 20 个抽样间隔 ($20\Delta t$) 后开始逐渐出现故障, 故障使得圆筒 T2 的液位 h_2 不能保持初始值而大幅下降. 采用粒子规模 N 为 500, $p=5$, $m=3$, $q=5$, 初始粒子满足 $x_0 \sim N([h_1^0 \ h_2^0 \ h_3^0]^T, 10^{-2})$. 系统初期是正常工作状态 ($t < 20$), 本文方法监测圆筒 T2 的液位, 每隔一个时间点进行正向预测计算其正常度, 同时反向预测与前期设备正常工作状态实际历史序列代入公式(5)和(7)计算其反常度, 当出现反常度连续两次大于正常度, 则预报出现故障. 实验结果如下表 1 和图 3, 表 2 中对比方法的实验结果来自文献[12]. 为比较本文故障预报方法和标准粒子滤波故障预报方法的计算量, 分别在 $N=1000, 2000, 3000, \dots, 5000$ 时对两种算法分别运行 10 次, 其平均运行时间 t_1 (本文方法) 和 t_2 (标准粒子滤波算法) 见表 3.

表 1 本文方法仿真实验的故障预报结果

时间点 t	54	55	56	57	58
T2 液位	0.2817	0.2808	0.2801	0.2787	0.2779
正常度 H	0.5688	0.5658	0.5836	0.5889	0.6004
异常度 F	0.6095	0.6084	0.5973	0.5899	0.5789
预报故障	无	无	无	无	/
时间点 t	59	60	61	62	63
T2 液位	0.2777	0.2768	0.2760	0.2747	0.2734
正常度 H	0.6390	0.6583	0.6684	0.6918	0.6859
异常度 F	0.5699	0.5451	0.5375	0.5119	0.4969
预报故障	有	有	有	有	有

表 2 对比方法仿真实验的故障预报结果

时间点 k	62	63	64	65	66
T2 液位	0.2783	0.2742	0.2761	0.2723	0.2742
故障概率	0.3709	0.4526	0.5250	0.5734	0.6425
预报故障	无	无	有	有	有
时间点 k	67	68	69	70	71

T2 液位	0.2705	0.2717	0.2685	0.2698	0.2666
故障概率	0.7211	0.7133	0.8326	1.0000	1.0000
预报故障	有	有	有	有	有

表 3 平均运行时间(s)

粒子数 N	1000	2000	3000	4000	5000
t ₁	16.32	30.57	44.59	57.31	73.98
t ₂	16.54	31.49	46.87	59.73	77.36




图 2 圆筒 T1、T2、T3 液位变化

图 2 表示圆筒 T1、T2、T3 实际液位及粒子滤波跟踪预测值的变化情况,从图 2 可以看出本文采用的粒子滤波算法对圆筒 T1、T2、T3 实际液位跟踪效果较好.

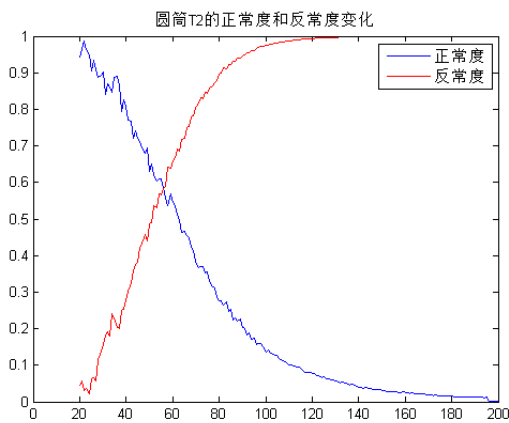


图 3 三容水箱实验的仿真结果

从图 3 以及表 1、2 中可以看出,本文采用方法在 $t=59\Delta t$ 预报故障,比对比的故障预报方法提早了 5 个

时间点,验证了本文方法的可行性,且其性能优于对比方法.

实验二是对 H-60 行星齿轮盘的裂纹故障进行预报,目标是发现该裂纹何时开始增大.反映裂纹长度变化的特征是观测到的震动信号谱中的谐波与边频带的比率数据,该数据有 251 个时间点一维样本.该系统离散化的状态空间模型为:

$$\begin{cases} x(k+1) = x(k) + \beta \cdot x(k) \cdot z(k) + u(k) \\ y(k) = x(k) + v(k) \end{cases} \quad (10)$$

上述模型中, $z(k)$ 为系统健康和故障状态,系统的状态变量 x 与裂纹长度相关,系统高斯系统噪声满足 $u \sim N(0, 1 \times 10^{-4})$, β 是与行星齿轮盘相关的时变参数,设置为 $(\sin(0.2k) + 1)/2$, y 为观测变量,高斯观测噪声满足 $v \sim N(0, 1 \times 10^{-2})$.

在实验中,251 个数据点对应 251 个时间点,粒子规模为 500, $p=5$, $m=2$, $q=5$,初始粒子满足 $x_0 \sim N(3.4, 0.64)$.设备故障发展初期为正常状态,每隔 $10\Delta t$ 进行 p 步向前预测计算其正常度,同时反向预测过去的状态得出预测值序列计算其反常度.当连续出现反常度两次大于正常度的情况,则预报出现故障,实验结果参见表 4 和图 4,并与基于粒子滤波的 FDI 方法^[13]的实验结果(图 5)进行对比.

表 4 本文方法仿真实验的故障预报结果

时间点 t	90	100	110	120	130	140
正常度H	0.5698	0.5928	0.5292	0.5391	0.4637	0.4727
反常度F	0.4232	0.4235	0.4457	0.6017	0.7038	0.7244
预报故障	无	无	无	/	有	有

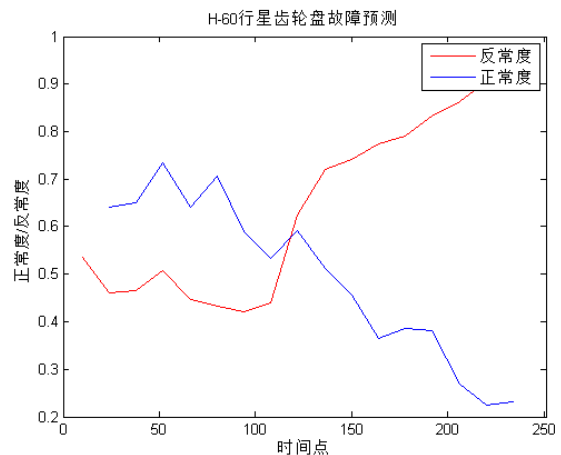


图 4 H-60 行星预报裂纹故障仿真结果




图5 基于粒子滤波的FDI方法裂纹故障预报结果

从图4及表4中可以看出,随着时间推移和潜在故障的发展,反常度逐步上升,正常度逐步下降.本文方法在 $t=130$ 时预报出现故障,对比方法基于粒子滤波的FDI提早了5个时间点预报出现故障.基于粒子滤波的FDI方法的基本原理为通过粒子滤波算法预测系统状态并根据相应的模型计算出当前时刻的故障概率从而实现对故障的预报,本文设计了设备符合正常工作状态程度的正常度和偏离正常工作状态的异常度,能更及时有效地对故障进行早期预报,实验结果验证了该方法的可行性.

5 总结

本文通过粒子滤波算法对目标系统进行跟踪及预测,采用动态时间匹配弯曲从正向及反向两个角度计算其反常度和正常度,从而实现对故障的预报.实验结果表明本文算法的有效性,并能及时准确的预报出故障.本文采用DTW算法度量序列之间的相似性,可以对设备的监测时间序列进行更灵活的分析.

参考文献

- Sun B, Kang R, Xie JS. Research and application of the prognostic and health management system. *System Engineering and Electronics*, 2007, 29(10): 1762–1767
- 景博,黄以锋,张建业.航空电子系统故障预测与健康管理工作现状与发展. *空军工程大学学报(自然科学版)*, 2010, 11(6):1–6.
- 杨占才,安茂春,王红.对发展故障预测和健康管理工作技术的探讨. *测控技术*, 2012, 31(11).
- 曾声奎, Pecht MG, 吴际.故障预测与健康管理工作(PHM)技术的现状与发展. *航空学报*, 2005, 5: 626–632.
- 刘志仓.基于粒子滤波的非线性系统故障诊断与预测方法研究[硕士学位论文].西安:西安电子科技大学, 2013
- Das Sarma A, Benjelloun O, Halevy A, Widom J. Working models for uncertain data. *Proc. of ICDE*. 2006.
- 胡士强,敬忠良.粒子滤波算法综述. *控制与决策*, 2005, 20(4):362–365,371.
- Chan KP, et al. Haar wavelets for efficient similarity search of time-series: With and without time wrapping. *IEEE TKDE*, 2003: 686–705.
- Kim DY, Moongu jeon: Spatio-temporal auxiliary particle filtering with L1-norm-based appearance model learning for robust visual tracking. *IEEE Trans. on Image Processing*, 2013, 22(2): 511–522.
- Salvador S, Chan P. Toward accurate dynamic time warping in linear time and space. *Intelligent Data Analysis*, 2007, 11(5): 561–580.
- 李俊奎,时间序列相似性问题研究[博士学位论文].武汉:华中科技大学,2008.
- 张琪,胡昌华,乔玉坤,蔡艳宁.基于随机摄动粒子滤波器的故障预报算法. *控制与决策*, 2009, 24(2):284–288.
- Orchard M, Vachtsevanos G. A particle filtering approach for on-line fault diagnosis and failure prognosis. *Trans. of the Institute of Measurement and Control*, 2009, 31(3-4): 221–246.
- Keogh E. Exact indexing of dynamic time wrapping. *VLDB*. 2002. 406–417
- Kim SW, et al. An index-based approach for similarity search supporting time wrapping in large sequence database. *ICDE*. 2001. 607–614
- Vaswani N, Rathi Y, Yezzi A, Tannenbaum A. Tracking deforming objects using particle filtering for geometric active contours. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2007, 29(8).
- Arulampalam MS, Maskell S, Gordon N, Clapp T. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking. *IEEE Trans. on Signal Processing*, 2002, 50(2): 174–188.
- Ristic B, Arulampalam S, Gordon N. Beyond the Kalman Filter: Particle Filters for Tracking Applications. Artech House, 2004.
- Liu JS, Chen R. Sequential Monte Carlo methods for dynamic systems. *Journal of the American Statistical Association (Taylor & Francis Group)*, 1998, 93(443): 1032–1044
- Djuric PM, Kotecha JH, Zhang JQ, et al. Particle filtering.

- IEEE Signal Processing Magazine, 2003, 20(5):19–38.
- 21 Mo YW, Xiao DY. Evolutionary particle filter and its application. Control Theory and Application, 2005, 22(2): 269–270.
- 22 Chang C, Ansari R. Kernel particle filter for visual tracking. IEEE Signal Processing Letters, 2005, 12(3): 242–245.
- 23 Xu Z, Ji Y, Zhou D. A new real-time reliability prediction method for dynamic systems based on on-line fault prediction. IEEE Trans. on Reliability, 2009, 58(3): 523–538.
- 24 Orchard M, Vachtsevanos G. A particle filtering approach for on-line fault diagnosis and failure prognosis. Trans. of the Institute of Measurement and Control, 2009, 31(3-4): 221–246.
- 25 Freitas ND. Rao-Blackwellised particle filtering for fault diagnosis. IEEE Aerospace Conference Proceedings, 2002, 4: 1767–1772.
- 26 Xie XQ, Zhou DH, Jin YH. Strong tracking filter based adaptive generic model control. Journal of Process Control, 1999, 9(4): 337–350.
- 27 Doucet A, Godsill SJ, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering. Statistics and Computing, 2000, 10(3): 197–208.
- 28 Tao W, Huang YF, Chen P. Particle filtering for adaptive sensor fault detection and identification. Proc. of the 2006 IEEE Int Conf on Robotics and Automation. Orlando, 2006: 3807–3812.